



EESTI MAAÜLIKOOL

Metsandus- ja maaehitusinstituut

Mihkel Kaha

**PUISTUTE LIIGILISE KOOSSEISU HINDAMINE
MULTISPEKTRAALSETE SATELLITPILTIDE PÕHJAL**

ESTIMATION OF SPECIES COMPOSITION IN FOREST
STANDS USING MULTISPECTRAL SATELLITE IMAGES

Magistritöö

Loodusvarade kasutamise ja kaitse õppekava

Juhendaja: vanemteadur Mait Lang, *PhD*

Tartu 2017

Eesti Maaülikool Kreutzwaldi 1, Tartu 51014		Magistritöö lühikokkuvõte	
Autor: Mihkel Kaha		Õppekava: Loodusvarade kasutamine ja kaitse	
Pealkiri: Puistute liigilise koosseisu hindamine multispektraalsete satelliitpiltide põhjal			
Lehekülgi: 40	Jooniseid: 3	Tabeleid: 7	Lisasid:0
Osakond: Metsakorralduse osakond Uurimisvaldkond: Kaugseire (T181) Juhendaja: Mait Lang Kaitsmiskoht ja -aasta: Tartu, 2017			
<p>Puistute liigilise koosseisu info on kasulik nii looduskaitse korraldamisel kui ka metsade majandamisel, kuna see kirjeldab metsade liigirikkust ning on vajalik metsakasvatustlike võtete planeerimisel. Metsade liigilist koosseisu määratakse peamiselt takseerimise teel, mis on ajamahukas töö. Kaugseire andmeid ja andmetöötlust kasutades on võimalik kiirelt anda ligikaudne hinnang suurtele aladele.</p> <p>Uurimustöö eesmärk oli testida puistute liigilise koosseisu hindamist multispektraalsete satelliidipiltide abil kasutades kasvuperioodi käigus puistute spektraalses signatuuris toimuvaid muutusi.</p> <p>Töös on kasutatud kolme erineva satelliidi multispektraalsete sensorite aegridade ülesvõtteid aastatest 2000 ja 2015. Analüüsi meetodina on kasutatud k-lähima naabri algoritmi.</p> <p>Töö tulemusena selgus, et näiteks männi, kuuse ja vanemate kaasikute puhtpuistud eristusid küllaltki hästi, mida näitas ka kuni väärtuseni 0,9 küündinud Kappa kokkulangevuse indeks. Teiste uuritavate klasside eristamine osutus keerukamaks, nimelt heitlehiste puuliikide, mille spektraalne signatuur samades fenoloogilistes etappides on üsna sarnane, täpsemaks kaardistamiseks peab tulevastel uurimustes kasutama täiendavaid kirjeldavaid tunnuseid.</p>			
Märksõnad: kaugseire, puistu liigiline koosseis, satelliidipildid, k-lähima naabri meetod			

Estonian University of Life Sciences Kreutzwaldi 1, Tartu 51014		Abstract of Master's Thesis	
Author: Mihkel Kaha		Speciality: Natural Resources Management	
Title: Estimation of species composition in forest stands using multispectral satellite images			
Pages: 40	Figures: 3	Tables: 7	Appendixes: 0
Department: Department of forest management Field of research: Remote sensing (T181) Supervisor: Mait Lang Place and date: Tartu, 2017			
<p>Information about stand species composition is useful for many applications in nature preservation and forest management, because it helps to describe biodiversity and creates a basis for better planning of silvicultural interventions. Forest species composition is usually acquired from forest inventory, but the fieldwork is time consuming. Remote sensing methods can quickly provide an approximate estimation for large areas.</p> <p>The aim for this study is to test the species composition estimation using multispectral satellite images based on phenology induces changes in spectral signature.</p> <p>Three different multispectral satellite image series were used in this study from years 2000 and 2015. An implementation of k-nearest neighbour algorithm provided by IDRISI spatial analysis environment was used to analyse the data.</p> <p>The work showed that pure stands of pine, spruce and older birch were well distinguished from others with Kappa indexes of agreement reaching to 0.9. However, to distinguish some classes from each other turned out to be troublesome. The discrimination of deciduous tree species from each other, which have very similar spectral signatures during the same phenological stages, calls for future studies to be conducted by using additional descriptive features.</p>			
Keywords: remote sensing, stand species composition, satellite images, k-nearest neighbour classifier			

SISUKORD

Lühendite ja tähiste loetelu.....	4
Sissejuhatus	5
1 Kirjanduse ülevaade	7
1.1 Puistute liigiline koosseis.....	7
1.2 Puistu peegeldusspektrit mõjutavad tegurid	7
1.3 Klassifitseerimine	9
2 Materjal ja metoodika.....	11
2.1 Uuritava ala kirjeldus.....	11
2.2 Kasutatud materjalid ja tarkvara	12
2.3 Metoodika	14
2.3.1 Õpetus- ja kontrollalade valik.....	14
2.3.2 Signatuuride loomine ja k-NN meetodi rakendamine	15
2.3.3 Tulemuste valideerimine	17
3 Tulemused	18
3.1 2015. aasta Landsat-8 OLI piltide aegrida.....	19
3.2 2015. aasta Sentinel-2 MSI piltide aegrida.....	22
3.3 2000. aasta Landsat-7 ETM+ piltide aegrida.....	26
4 Arutelu.....	30
Kokkuvõte	33
Kasutatud kirjandus	35
SUMMARY	38

LÜHENDITE JA TÄHISTE LOETELU

ETM+	-	Enhanced Thematic Mapper Plus
HB	-	Haab
k-NN	-	k-nearest neighbors algorithm
KS	-	Kask
KU	-	Kuusk
LM	-	Sanglepp
MA	-	Mänd
MSI	-	MultiSpectral Instrument
OLI	-	Operational Land Imager
SMEAR	-	Station for Measuring Ecosystem-Atmosphere Relations
SQL	-	Structured Query Language

SISSEJUHATUS

Info puistute liigilise koosseisu kohta on oluline nii elurikkuse kirjeldamisel, atmosfääri lenduvate orgaaniliste ühendite hulga hindamisel kui ka metsamajanduslike otsuste kavandamisel (Ørka et al. 2013, Jansson, Angelstam 1999). Puistu liigilist koosseisu kirjeldatakse tavaliselt koosseisuliikide rinnaspindalade või tüvemahtude osakaalude abil või noorendikes ka puude arvu järgi (Metsa korraldamise... 2009, § 12 lg 2). Puistute liigilise koosseisu andmed saadakse tavaliselt metsa takseerimisel, aga metsa takseerandmeid uuendatakse üsna pika ajalise intervalliga või siis pööratakse tähelepanu pigem neile puistutele, kus vajadus metsakasvatustlike võtete rakendamiseks võib olla suurem. Eestis puistutes on enamlevinud kaks igihaljast okaspuuliiki (harilik kuusk ja harilik mänd) ja viis heitlehist puuliiki (arukask, sookask, harilik haab, hall lepp ja must lepp). Uurimustöö eesmärgiks on testida puistute liigilise koosseisu hindamist multispektraalsete satelliidipiltide abil kasvuperioodi käigus puistute spektraalses signatuuris toimuvate muutuste järgi.

Nii Euroopa kosmoseprogrammi Copernicus raames orbiidile lähetatud satelliidil Sentinel-2 oleva skanneri MultiSpectral Instrument (MSI) kui ka NASA satelliidil Landsat-8 oleva skanneri Operational Land Imager (OLI) ülesvõtted on oluliselt suurema radiomeetrilise lahutusvõimega kui varasemad satelliidipildid, mis võimaldab paremini tuvastada väiksemaid erinevusi puistute spektraalses signatuuris. Sõltuvalt puuliigist ja kasvutingimustest lähevad puud lehte kevadel erinevatel aegadel ning tihti jõuavad ühest fenofaasist teise erinevatel perioodidel, mis annab pilditöötluses võimalusi nende omavaheliseks eristamiseks. Igihaljaid okaspuid võiks aga kevadistelt ja sügisestelt piltidelt eristada lehtpuudest, millel lehti küljes pole lisaks nende suvisele suurele erinevusele spektri lähiinfrapunases osas.

Uuritavaks katsealaks oli Järvelja Õppe- ja Katsemetskond. Nende metsade kohta on olemas üsna detailne digitaalne takseerandmestik, milles on puistute kaart ja ka puistuelementide kirjeldused. Seega saab hästi kontrollida pilditöötluse tulemuste headust. Takseerandmestik on lisaks metsamajanduse kavandamisele oluline ka Järveljal asuva

SMEAR - Estonia mastis (Noe et al. 2015) tehtavate voomõõtmiste tulemuste tõlgendamiseks. Siiski ei kata see Järvelja metsakorralduse andmestik tervet seda maa-ala, millel toimuvad protsessid mõjutavad oluliselt SMEAR mastis olevate sensorite lugemeid. Kaugseire meetodite abil on võimalik aga koostada metsade kaardid ka neile aladele, kus metsakorralduse andmestik puudub või on vananenud. Mittekontaktsete meetodid arvatavasti ei asenda ega ületa täpsuse poolest vilunud metsataksaatori koostatud takseerikirjeldusi ja tegelikult polegi neid kaht viisi vaja vastandada. Pigem tuleb koostada andmetöötluse mudelid, kus mõlema meetodi võimalusi kasutatakse. Järvelja Öppe- ja Katsemetskonna metsamaast suure osa moodustavad looduskaitsealad, kus majandustegevus on piiratud või üldse välistatud. Seetõttu saaks nendel aladel puistute jälgimisel kasutada suurema kaaluga kaugseiret ja taksaatoril oleks võimalus keskenduda neile metsadele, kus struktuuri kirjeldamise täpsus on oluline majandusotsuste kavandamisel.

Uurimustöös on kasutatud Sentinel-2 MSI, Landsat-8 OLI ja Landsat-7 ETM+ multispektraalseid satelliitülesvõtteid. Lisaks on kasutatud Järvelja Öppe- ja Katsemetskonna takseerandmestike aastatest 2001 ja 2011. Analüüsi käigus on kasutatud ka Maa-ameti 2002 ja 2014 aasta ortofotosid ning Corine Land Cover projekti 2000. aasta maakatte kaarti.

Andmete analüüsiks valiti välja peamiste puuliikide puhtpuistuid iseloomustavad õpetusalad ning neile koostati spektraalsed signatuurid. Neid kasutati k-lähima naabri algoritmis, et koostada puistute liigilise koosseisu kaardid. Kaardi kontrolliks kasutati õpetusaladele sõltumatud kontrollalade valimit ning tulemuste headuse kirjeldamiseks arvutati kappa kokkulangevuse indeksid.

1 KIRJANDUSE ÜLEVAADE

1.1 Puistute liigiline koosseis

Puistute liigiline koosseis on oluline informatsioon looduse kaitse ja metsade majandamise kavandamisel kui ka näiteks linnades. Puuliikide valik linna parkides ja alleedes on oluline, kuna puuliigist sõltuvalt on nende võime õhureostust vähendada erinev. Okaspuud ja keerulisema võrastruktuuriga puud on efektiivsemad saasteaine õhust kinni püüdmisel. Kuid tuleb arvestada ka puude tekitavate bioloogiliste lenduvate orgaaniliste ühenditega, mis võivad osaleda reaktsioonides teiste aerosoolidega ning mõjutada osooni hulka õhus (Beckett et al. 2000, Calfapietra et al. 2013). Puistute liigilise koosseisu informatsiooni saab kasutada näiteks tüvemahu või biomassi mudelites. Liigilist koosseisu on oluline teada metsakasvatustlike võtete kavandamisel. Lisaks määratakse liigilise koosseisu järgi elupaigatuüp ja liikide osakaal mõjutab selle kvaliteeti ning bioloogilist mitmekesisust. Seega on puistute liigilise koosseisu hindamine üks olulisemaid töid metsa inventeerimisel. (Ørka et al. 2013, Fassnacht et al. 2016, Jansson, Angelstam 1999)

Liigilise koosseisu informatsiooni on tihti vaja suurte alade kohta. Viimastel aastakümnetel on kaugseiretehnoloogia kiirelt arenenud ja on välja töötatud suurema ruumilahutuse ja radiomeetrilise tundlikkusega sensorite tüüpe, mida saab kasutada puuistute struktuuri ja liigilise koosseisu hindamiseks (Fassnacht et al. 2016).

1.2 Puistu peegeldusspektrit mõjutavad tegurid

Taimelehtede peegeldusspektri võib üldjoontes jagada kolmeks osaks: ultravioletne (0,3 – 0,38 μm), nähtava valguse (0,38 – 0,72 μm) ja infrapunane (0,72 – 3 μm) osa. Pikematel kui 3 μm infrapunastel lainepikkustel on kiirgus juba enamjaolt taime enda poolt emitteeritud. Taimelehtedes on peamisteks kiirgust neelavateks osadeks lehepigmentid ja vesi (Hoffer, Johannsen 1969). Lehepigmentideks on näiteks klorofüll a ja b, erinevad

karotinoidid ja tanniin. Nende peamised neeldumisspektrid asuvad spektri nähtavas piirkonnas. Samas on vee neeldumisribad aga spektri lähi- ja keskmises infrapunases piirkonnas. Taimelehtedes esinevad teised elemendid neelavad kiirgust vähem ja teevad seda peamiselt spektri ultravioletses ja sinises piirkonnas. Kuid Maa atmosfäär neelab suurel määral ultraviolettkiirgust ja seega pole need lainepikkused kaugseires hästi kasutatavad (Nilson 1994, Hoffer, Johannsen 1969).

Kuna erinevatel taimeliikidel on lehed oma pigmentide osakaalu suhtes küllaltki sarnased, siis on ka nende peegeldumis- ja läbilaskepektrid raskesti eristatavad. Lisaks teeb liikide eristamise keerulisemaks ka see, et ühe ja sama taimeliigi lehed võivad, sõltuvalt kasvutingimustest, omada erinevaid optilisi omadusi. Kuid siiski on erinevatel puuliikidel neilt tagasi peegelduva kiirguse heledused erinevad. Okaspuud on näiteks spektri lähiinfrapunases osas tumedamad kui lehtpuud ning kuused on üldiselt spektri optilises osas tumedamad kui männid. Kui segametsas suureneb lehtpuude osakaal, siis suureneb ka neilt tagasi peegelduva lähiinfrapunase kiirguse osakaal. Kõige lihtsam männikut ja kuusikut omavahel eristada on aga kasutada keskmise infrapunase kiirguse andmeid. (Nilson 1994)

Üheliigilise puistu heleduskoefitsient sõltub oluliselt puuliigile omasest lehe või okka peegeldus- ja läbilaskekoefitsiendist, lehtede või okaste kogupindalast ja võra kujust. Lisaks neile on puu võra heleduse moodustamisel oluline ka foon ja selle valgustatus. Fooniks metsas on alusmets, rohu- ja puhmarinne ning järelkasv. Fooni valgustatus sõltub aga suurel määral päikesekiirte langemise suunast ja puistu läbipaistvusest. Üldjuhul on kogu puistu heleduskoefitsient väiksem kui selle osad eraldi, kuna elementide koosmõjul toimub metsas vastastikune varjutamine. (Nilson 1994)

Puistute heledust mõjutab oluliselt ka nende vanus. Puistu heledus vanuse kasvades väheneb peaaegu kõigis spektri piirkondades. Heledus muutub ajaliselt kõige kiiremini just noortes puistutes, mingist vanusest heledus stabiliseerub ja muutub vähe (Nilson, Peterson 1994). Selle heleduse vähenemise peamisteks põhjusteks loetakse varjude osakaalu suurenemist, mida omakorda põhjustab puistu liituse ja lehepinnaindeksi suurenemist. Kui pärast puistu liitumist teised metsanduslikult olulised parameetrid nagu puu kõrgus, tüve diameeter, tagavara ja rinnaspindala jätkavad oma kasvu, ei mõjuta need oluliselt puistu üldist heledust, kuna liitus ja lehepinnaindeks jäävad enam-vähem samale tasemele (Nilson 1994).

Taimeliikide optilised omadused on aastaajast sõltuvad. Seda eriti just spektri nähtavas osas. Seega saab suvise spektraalse signatuuri poolest sarnaste liikide omavaheliseks eristamiseks kasutada arvatavasti mitmel erineval kuupäeval tehtud pilte. Kuigi eri liiki puudel võib samal fenoloogia arengujärgul olla väga sarnane peegeldusspekter, siis erinevatel puuliikidel toimuvad fenoloogilised muutused aasta jooksul erinevatel aegadel. Kui on võimalik valida satelliitpilte ajahetkedest, mil puude fenoloogilised astmed oleksid teineteisest erinevad, siis võimaldaks see puuliike teineteisest hõlpsamalt eristada. (Nagendra 2001, Kremer, Running 1993, Wolter et al. 1995)

Kui kasutada satelliidipiltide aegridu, siis on paljusid puu- ja taimeliike võimalik teineteisest küllaltki suure täpsusega (60-100%) eristada. Seda aga juhul kui tegemist on üsna homogeensete aladega ja satelliitpiltidelt on saadavalt piisavalt seda ala kirjeldavaid pikseleid. Mida heterogeensemaks muutuvad uuritavad alad ja mida rohkem uuritavaid klasse proovitakse eristada, seda raskemaks muutub nende kaardistamine kaugseire meetodite abil. (Nagendra 2001, Kremer, Running 1993, Wolter et al. 1995)

1.3 Klassifitseerimine

Kui satelliitpiltide pikslid ei ole taimestiku struktuuri ja selle alusel kujunenud spektraalse signatuuri poolest selgelt eristuvad, siis raskendab see täpsete kaartide koostamist (Thessler et al. 2005). Majandusmetsas eraldatakse puistud liigilise koosseisu ja metsa struktuuri järgi võrdlemisi homogeenseteks osadeks, mis on tavaliselt küllaltki diskreetsed ja selgelt eristatavate piiridega. Aga näiteks reservaatides, kus on aga tegemist looduslikult uuenevate, erivanuseliste ja erinevatest liikidest puudega ühtlase alaga, on üleminekud sujuvad ja piirid ei ole nõnda lihtsalt eristatavad. Samas võivad ka tulundusmetsa eraldised olla varieeruva struktuuriga segapuistud ja liigilise koosseisu määramine sellistes heterogeensetes puistutes on üsna keeruline. Seega on mõttekas klassifitseerimisel kasutada segametsade klassi ka majandusmetsade kaartide koostamisel, et tõsta kaardistuse täpsust. (McRoberts et al. 2002, Salovaara et al. 2005)

Paljudes riikides, nagu näiteks Soomes, on maakasutuse liigid aladel harva muutuvad ja need on üle riigi hästi kaardistatud. Seega saab neid kaarte kasutades metsade hindamisel kaugseire meetodite jaoks eraldada metsamaa muu kasutuviisi maadest nagu näiteks

põllumaast või inimasustusest. Seesugust eeltingimust rakendades saab klassifitseerimis-meetodeid kasutades suure kindlusega väita, et metsa klassi ei satu kogemata teise kasutuse alla kuuluvaid piksleid (Katila, Tomppo 2002, Tomppo, Halme 2004). Samas näiteks Põhja-Ameerikas on paljud maa-alad oma kasutuse poolest tihedalt muutuvad ja usaldusväärset maakasutuse kaarti pole tihti saadaval. Kasutades metsanduslikes rakendustes laialt levinud k -lähima naabri meetodit võib sel juhul tihti sattuda täiesti erinevat tüüpi alade piksleid samasse klassi. Kuigi reaalsuses ei pruugi uuritav ala metsa alla kuuluda, siis k -NN algoritm võib sellest hoolimata sinna paigutada metsa klassi piksleid. Selle tagajärjel võib juhtuda, et metsade takseerkirjeldused koostatakse ka mittemetsamaa pikslitele ja metsamaa kirjeldusi alahinnatakse. (McRoberts et al. 2002)

2 MATERJAL JA METOODIKA

2.1 Uuritava ala kirjeldus

Selle töö raames on uuritavaks alaks valitud Järvelja Õppe- ja Katsemetskond ning selle lähem ümbrus. Järvelja küla asub Tartumaa kaguosas. Metskonna kogupindala on 10 396 ha (tabel 1), millest metsamaa alla kuulub 6626 ha. Suur osa (3147 ha) metskonna põhjapoolsest alast on soo. Üle poole kogu metskonnast on looduskaitse all, kuid metsadest on kaitse all 41% (2723 ha). (Metsanduslik... 2017, Järvelja loodus 2017)

Tabel 1. Ülevaade eraldiste jagunemisest kõlvikuliikide kaupa Järvelja Õppe- ja Katsemetskonnas (Järvelja metsamajandamise... 2017a)

Kõlviku		Eraldiste		Kaitstav	
Nimetus	Kood	Pindala (ha)	Arv	Pindala (ha)	Osakaal %
Tootlik metsamaa	MT	6529,0	4248	2600,2	39,8
Vähetootlik metsamaa	MV	96,9	18	90,9	93,8
Soo	SO	3147,9	218	2998,0	95,2
Järv	JA	352,0	14	350,2	99,5
Põõsastik	PS	91,4	26	88,1	96,3
Jõgi	JG	64,5	13	64,5	100
Looduslik rohumaa	RM	60,2	41	21,2	35,2
Põllumaa	PM	20,7	20	3,7	17,9
Park	PK	13,0	5	1,9	14,4
Õuemaa	OU	11,1	7	0,4	3,7
Taimla	TA	4,2	3	0	0
Veehoidla, tiik	VH	2,8	14	0,8	28,4
Pinnaveeala	PV	1,3	3	0	0
Karjäär	KJ	0,8	4	0,1	11
Muu maa	XM	0,8	4	0	0
		10396,5	4638	6219,9	59,8

Tabelis 2 on toodud Järvelja Õppe ja Katsemetskonna puistute jaotus peapuuliigi alusel. Enamus metsadest on kaasikud, võttes enda alla ligikaudu 58% kogu metsamaa pindalast. Kogupindalalt järgnevad männikud (ligikaudu 20%), kuusikud (ligikaudu 11%) ja

sanglepikud (ligikaudu 7%). Teised puuliigid on tunduvalt vähem esindatud. Keskmine eraldise pindala on veidi üle pooleteise hektari. Üldkokkuvõttes on Järvelja Õppe ja katsemetskonna aladel puhtpuistuid, mille peapuuliigi osakaal ületab 90%, kogupindalast 48,1%. Suure osa neist moodustavad kaasikud ja männikud. Üle poole metsade pindalast katavad segapuistud, kus peale peapuuliigi kasvab ka arvestataval määral teisi puuliike.

Tabel 2. Puistute jagunemine peapuuliigi järgi Järvelja Õppe ja Katsemetskonnas (Järvelja metsamajandamise... 2017b)

Peapuuliik	Eraldise pindala (ha)		Peapuuliigi koefitsiendi osakaal kogupindala suhtes						
	Kogu	Keskmine	90-100%	80-89%	70-79%	60-69%	50-59%	40-49%	<40%
Kask	3850,8	1,8	51,0%	11,6%	14,2%	13,5%	6,5%	2,2%	0,9%
Mänd	1299,3	1,6	62,3%	9,1%	12,8%	10,0%	4,1%	1,7%	0,1%
Kuusk	754,6	1,0	22,2%	18,0%	15,3%	18,4%	17,9%	4,6%	3,5%
Sanglepp	496,4	1,4	12,9%	18,1%	19,7%	22,0%	17,0%	7,9%	2,4%
Haab	149,0	1,0	16,3%	13,9%	20,0%	23,4%	16,2%	9,3%	0,8%
Pärn	31,3	0,9	8,9%	5,8%	16,2%	26,3%	14,3%	7,7%	20,8%
Hall lepp	16,9	0,6	32,1%	6,0%	32,6%	18,5%	10,9%	0,0%	0,0%
Lehis	12,7	0,6	22,1%	36,0%	19,8%	12,8%	9,3%	0,0%	0,0%
Teised okaspuud	7,6	0,5	13,0%	28,6%	0,0%	7,8%	9,1%	19,5%	22,1%
Saar	3,3	1,7	0,0%	0,0%	0,0%	0,0%	17,6%	0,0%	82,4%
Tamm	2,7	0,5	13,2%	50,0%	7,9%	0,0%	0,0%	0,0%	28,9%
Nulg	1,2	0,2	80,0%	0,0%	0,0%	20,0%	0,0%	0,0%	0,0%
Ebatsuuga	0,2	0,2	0,0%	0,0%	0,0%	100,0%	0,0%	0,0%	0,0%
Kokku	6625,9	1,6	48,1%	12,0%	14,4%	13,7%	7,8%	2,8%	1,2%

2.2 Kasutatud materjalid ja tarkvara

Lähtematerjalina on selles töös kasutatud kolme erineva skanneri multispektraalseid pilte. Landsat-7 ETM+ multispektraalsed pildid pärinevad aastast 2000. Pildid on tehtud neljal erineval kuupäeval 23. aprill; 09. mai; 10. juuni ja 30.september. Kanalite ruumilahutus maapinnal on 30 m

Landsat-8 OLI andmed pärinevad aastast 2015 ja on kuupäevadest 17. märts; 4. mai; 12. juuli; 8. august; 24. august ja 3. november. Ka nende piltide ruumilahutus maapinnal on

30 m. Lisaks on algses pildikomplektis ka pankromaatiline kanal ruumilahutusvõimega 15 m ja termiline kanal ruumilahutusega 60 m, kuid neid pilte selles uurimustöös ei kasutaud.

Sentinel-2 MSI andmed on samuti aastast 2015 ja nende ülesvõtete kuupäevad on 4. august; 11. august; 24. august; 30. september ja 3. oktoober. Sentinel-2 MSI spektraalkanalid on erinevad ruumilahutusega, millest osa on maapinna suhtes piksli suurusega 10 m ja osa 20 m. Andmetöötluste jaoks on 20 meetrise piksliga pildid teisendatud ümber 10 meetriste pikslitega piltideks. Lisaks on Sentinel-2 MSI andmetes ka kolm kanalit 60 m suuruste pikslitega, kuid neid selles uurimuses ei kasutatud.

Pildid on töötluste tarbeks teisendatud L-EST92 koordinaatsüsteemi ja lõigatud $13,05 \text{ km} \times 18,48 \text{ km}$ suurusteks, et mahutada informatsiooni kogu Järvelja Õppe ja Katsemetskonna ning natuke ka selle lähema ümbruskonna kohta. Pildid on valitud sedasi, et kogu uuritaval alal puuduks oluline pilvkate. Piltidele on enne uurimust tehtud atmosfääri korrektsioon tumeda objekti lahutamise meetodit (Dark Object Subtraction Model) kasutades. Selle operatsiooni jaoks kasutati IDRISI atmosfääri korrektsiooni moodulit ATMOSC ja sisendväärtused selle jaoks võeti automaatselt andmepaketiga kaasas olevast metaandmete failist.

Järvelja metsaeraldiste kohta on olemas detailsed takseerandmestikud digitaalsel kujul koos puistupiiride vektorkihiga. Takseerandmestikud pärinevad aastatest 2001 ja 2011 ja sisaldavad infot puistute liigilise koosseisu, boniteedi, kasvukohatüübi ja veel mitmete teiste takseertunnuste kohta.

Veel on töös kasutatud Corine Land Cover 2000 aasta maakatte kaarti ning Maa-ameti 2002 ja 2014 aasta ortofotosid.

Andmete töötlusteks kasutati programme IDRISI Taiga 16.05, Mapinfo Professional 12.0 ja Microsoft Excel 2010.

2.3 Metoodika

2.3.1 Õpetus- ja kontrollalade valik

Kasutades Järvelja Õppe ja Katsemetskonna takseerandmestiku selekteeriti eraldiste seast esmalt välja eraldisi kasutades SQL päringuid eesmärgiga leida näidiseid erineva peapuuliigi, vanuse ja liigilise koosseisuga puistutele. Päringuga valiti välja puhtkaasikud, -sanglepikud, -kuusikud, -männikud ja lagedad alad ning haavikud alates 75 % peapuuliigi osakaalust. Satelliitülesvõtte ajaks uuendusraiesse läinud lagedate alade leidmiseks kasutati ka Järvelja metsamajandamise infosüsteemi (Järvelja metsamajandamise... 2017c). Kokku valiti välja 192 erinevat ala.

Puhtpuistute valimisel oli oluline selekteerida võimalikult homogeenseid metsaeraldisi, sest variatsioon puistus mõjutab ka selle spektraalset signatuuri. Esmast valikut kontrolliti kasutades Maa-ameti ortofotosid vektorkihi taustal. Üldiselt selekteeriti eraldised nende määratud piiride järgi terviklikult, kuid vajadusel muudeti eraldise kuju valikukihis sõltuvalt metsade enda variatsioonist. Kohati oli näiteks pool eraldisest hiljuti läbinud raie või sisaldas eraldis mõnel muul põhjusel lagedaid alasid. Sel juhul moodustati uus vektorobjekt ortofoto järgi.

Näidiste valiku koostamisel otsiti suuremaid ja sisemiselt homogeenseid eraldisi, kuid kuna Järvelja Õppe ja Katsemetskonna eraldiste keskmine suurus on vaid poolteist hektarit ja mõne peapuuliigi puistutel veelgi vähem (tabel 4), siis paljudel juhtudel ei jäänud muud võimalust, kui jätta valikusse ka väga väikese pindalaga näidiseid. Nimelt kui valikute vektorkiht teisendada ümber sama skaalaga rasterkaardiks, nagu seda on satelliitpildid (30 m), siis jäi mõne valikala suuruseks vaid 2 pikslit.

Peale näidisalade valimi kontrolli jagati see masinõppe aladeks ja tulemuse kontrollaladeks. Jälgiti, et igas tüübiklassis oleks üldiselt võrdselt esindajaid.

2.3.2 Signatuuride loomine ja k-NN meetodi rakendamine

IDRISI Taiga pilditötlustarkvara abil tehti õpetusalade signatuurfailid kasutades MakeSig moodulit. Saadud failid sisaldavad endas infot pikslite individuaalsete väärtuste kohta antud klassis ja kanalis ning vastava klassi miinimum ja maksimum väärtusi, keskmist väärtust ja variatsiooni iga sisendkanali kohta ning kovariatsiooni teiste kanalite suhtes.

Tabel 3. Katsete tähised kanali kombinatsioonide ja ülesvõtete aegrea kuupäevade järgi

Katse	Sensor	Kanalid	Kuupäevad	Aasta
kNNOLI1	OLI	1;2;3;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI2	OLI	2;3;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI3	OLI	1;3;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI4	OLI	1;2;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI5	OLI	3;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI6	OLI	4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI7	OLI	4;5;6	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI8	OLI	4;5;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI9	OLI	4;5;6;7	04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI10	OLI	4;5;7	04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI11	OLI	4;5;6	04.05; 12.07; 08.08; 24.08; 03.11	2015
kNNOLI12	OLI	4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08	2015
kNNMSI1	MSI	3;4;5;6;7;8;8A;11;12	04.08; 11.08; 24.08; 30.09; 03.10	2015
kNNMSI2	MSI	5;6;7;8A;11;12	04.08; 11.08; 24.08; 30.09; 03.10	2015
kNNMSI3	MSI	5;6;7;8A	04.08; 11.08; 24.08; 30.09; 03.10	2015
kNNMSI4	MSI	3;4;8A;11;12	04.08; 11.08; 24.08; 30.09; 03.10	2015
kNNMSI5	MSI	4;8A;11;12	04.08; 11.08; 24.08; 30.09; 03.10	2015
kNNMSI6	MSI	3;4;8A;11	04.08; 11.08; 24.08; 30.09; 03.10	2015
kNNMSI7	MSI	3;4;8A;12	04.08; 11.08; 24.08; 30.09; 03.10	2015
kNNMSI8	MSI	3;4;8A;11;12	04.08; 11.08; 24.08; 30.09	2015
kNNETM+1	ETM+	1;2;3;4;5;7	23.04; 09.05; 10.06; 30.09	2000
kNNETM+2	ETM+	2;3;4;5;7	23.04; 09.05; 10.06; 30.09	2000
kNNETM+3	ETM+	1;3;4;5;7	23.04; 09.05; 10.06; 30.09	2000
kNNETM+4	ETM+	1;2;4;5;7	23.04; 09.05; 10.06; 30.09	2000
kNNETM+5	ETM+	3;4;5;7	23.04; 09.05; 10.06; 30.09	2000
kNNETM+6	ETM+	4;5;7	23.04; 09.05; 10.06; 30.09	2000
kNNETM+7	ETM+	3;4;5;7	23.04; 09.05; 10.06	2000

Tabelis 3 on toodud kõik katsetatud satelliitide kanalite ja ülesvõtete kuupäevade kombinatsioonid, milledest loodi õpetusalade kohta signatuurid. Saadud signatuurfailide komplektid koos satelliitpiltide komplektidega olid sisendiks k-NN protseduurile.

K-NN algoritm klassifitseerib iga pildi piksli mingisse klassi, leides esmalt kauguse spektraalses ruumis õpetuseks kasutatavatest näidistest. Kasutatakse tavaliselt mitmemõõtmelist eukleidilist kaugust (D).

:

$$D = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad (2.1)$$

kus n on seletavate tunnuste (spektraalkanalite) arv ning x_i ja y_i vastavalt i-ndas kanalis sihtpiksli ja näidise y väärtused. K-NN algoritm leiab klassifitseeritavale pikslile spektraalses ruumis lähimad näidised õpetuspikslite seast ja konkreetne realisatsioon IDRISI paketi klassifitseerib piksli klassi, mille näidispikseleid oli nende k lähima naabri hulgas kõige rohkem.

Puistute liigilise koosseisu kaart koostati kahe sammuna. Esmasel klassifikatsioonil vastas iga näidisala individuaalselt ühele klassile. Seejärel k-NN klassifitseerimise tulemused koondati kaheksasse põhiklassi. Nendeks olid 2015 aasta andmete töötamise puhul: haavikud (vanuses 19-104 aastat), noored kaasikud (vanuses 5-12 aastat), vanemad kaasikud (14-69 aastat), kuusikud (vanuses 19-79 aastat), noored sanglepikud (vanuses 2-5 aastat), vanemad sanglepikud (vanuses 14-85 aastat), männikud (vanuses 54-164 aastat) ja lagedad alad, kus on uurimusandmete ajale eelnevalt tehtud lageraieid.

2000. aasta klassid olid väga sarnased 2015 aasta omadele, kuid sõltuvalt takseerandmetest ja tehtud valikutest olid puistute vanusevahemikud veidi teistsugused. Valikusse jäid haavikud (vanuses 40-85 aastat), noored kaasikud (vanuses 2-9 aastat), vanemad kaasikud (14-84 aastat), kuusikud (vanuses 18-109 aastat), noored sanglepikud (vanuses 6-12 aastat), vanemad sanglepikud (vanuses 14-94 aastat), männikud (vanuses 34-174 aastat) ja lagedad alad.

2.3.3 Tulemuste valideerimine

K-NN mooduli koondatud tulemust võrreldi kontrollaladega kasutades IDRISI Crosstab moodulit. See moodul moodustab risttabeli kahe pildi omavahelisest sobivusest ning arvutab ka kappa kokkulangevuse indeksi (Kappa Index of Agreement) kogu tabeli kohta ning ka iga klassi kohta eraldi. Kappa kokkulangevuse indeksit κ kirjeldab valem 2.2 (Cohen 1960, Landis, Koch 1977)

$$\kappa \equiv \frac{p_0 - p_e}{1 - p_e} = 1 - \frac{1 - p_0}{1 - p_e}, \quad (2.2)$$

kus p_0 on suhteline kokkulangevus ja p_e on hüpoteetiline eeldatav kokkulangevus, mis omakorda arvutatakse valemiga

$$p_e = \frac{1}{N^2} \sum_j n_{j1} n_{j2}, \quad (2.3)$$

kus N on objektide arv, j kategooriate arv ja n_{j1} ja n_{j2} vastavalt ennustuste arv kategoorias j

Kappa indeksi väärtused alla 0 tähendavad viletsat kokkulangevust, 0–0,20 mõningast, 0,21–0,40 rahuldavat, 0,41–0,60 mõõdukat, 0,61–0,80 olulist ja 0,81–1 peaaegu ideaalset kokkulangevust (Landis, Koch 1977). Kuid siinkohal tuleb mainida, et tegemist on siiski tõlgendatud subjektiivsete hinnangupiiridega.

3 TULEMUSED

Tabel 4 Klassifitseerimistulemused reastatud sensori ja kappa kokkulangevuse indeksi alusel

Katse	Kanalid	Pildid	Kappa
kNNOLI1	1;2;3;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	0,6572
kNNOLI2	2;3;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	0,6558
kNNOLI4	1;2;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	0,6558
kNNOLI3	1;3;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	0,6539
kNNOLI5	3;4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	0,6531
kNNOLI6	4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	0,6511
kNNOLI12	4;5;6;7	17.03; 04.05; 12.07; 08.08; 24.08	0,6472
kNNOLI7	4;5;6	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	0,6376
kNNOLI8	4;5;7	17.03; 04.05; 12.07; 08.08; 24.08; 03.11	0,6215
kNNOLI9	4;5;6;7	04.05; 12.07; 08.08; 24.08; 03.11	0,6143
kNNOLI10	4;5;7	04.05; 12.07; 08.08; 24.08; 03.11	0,6061
kNNOLI11	4;5;6	04.05; 12.07; 08.08; 24.08; 03.11	0,6029
kNNMSI1	3;4;5;6;7;8;8A;11;12	04.08; 11.08; 24.08; 30.09; 03.10	0,7086
kNNMSI4	3;4;8A;11;12	04.08; 11.08; 24.08; 30.09; 03.10	0,7084
kNNMSI2	5;6;7;8A;11;12	04.08; 11.08; 24.08; 30.09; 03.10	0,7016
kNNMSI5	4;8A;11;12	04.08; 11.08; 24.08; 30.09; 03.10	0,7007
kNNMSI6	3;4;8A;11	04.08; 11.08; 24.08; 30.09; 03.10	0,6994
kNNMSI8	4;8A;11;12	04.08; 11.08; 24.08; 30.09	0,6909
kNNMSI7	3;4;8A;12	04.08; 11.08; 24.08; 30.09; 03.10	0,6908
kNNMSI3	5;6;7;8A	04.08; 11.08; 24.08; 30.09; 03.10	0,6258
kNNETM+3	1;3;4;5;7	23.04; 09.05; 10.06; 30.09	0,5823
kNNETM+5	3;4;5;7	23.04; 09.05; 10.06; 30.09	0,5812
kNNETM+2	2;3;4;5;7	23.04; 09.05; 10.06; 30.09	0,5786
kNNETM+1	1;2;3;4;5;7	23.04; 09.05; 10.06; 30.09	0,5784
kNNETM+4	1;2;4;5;7	23.04; 09.05; 10.06; 30.09	0,5699
kNNETM+6	4;5;7	23.04; 09.05; 10.06; 30.09	0,5650
kNNETM+7	3;4;5;7	23.04; 09.05; 10.06	0,5515

Tabelis 4 on järjestatud katsetulemuste kappa näitaja alusel erinevate satelliitide ja nende aegridade analüüsid. Kanali ja aegrea ülesvõtete kombinatsioonide võrdlusest on näha, et

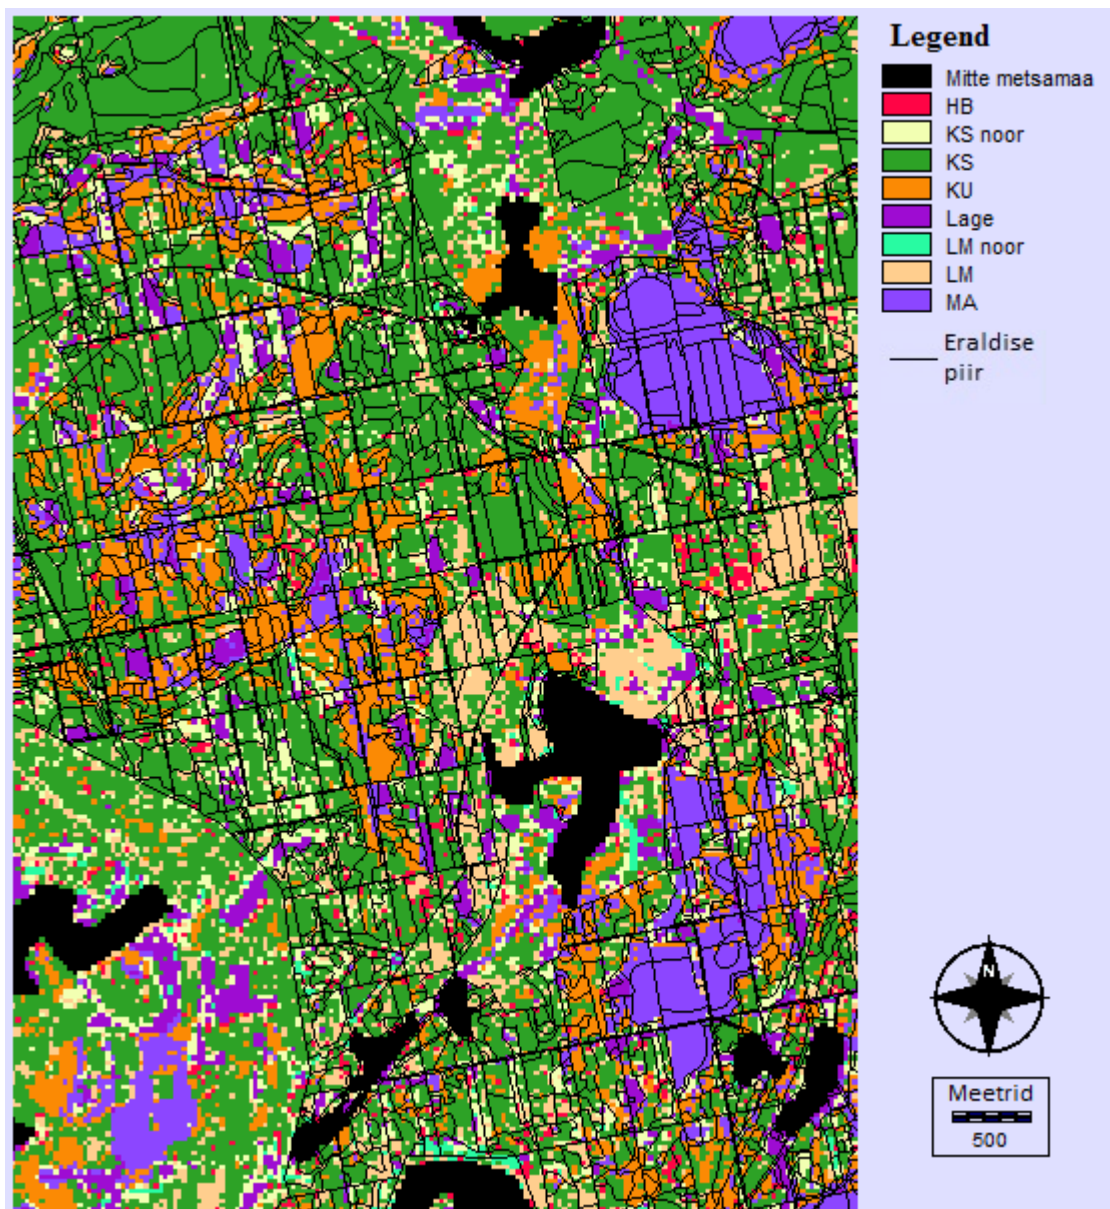
kindlasti annab klassifitseerimisel paremaid tulemusi lühilaineliste infrapunaste kanalite kaasamine analüüsi. Kui võrrelda katseid kNNMSI2, mis sisaldab lühilainelisi infrapuna kanaleid, ja kNNMSI3, mis neid ei sisalda, siis on selgelt näha kapp indeks langus umbes 0,08.

3.1 2015. aasta Landsat-8 OLI piltide aegrida

Landsat-8 OLI andmete analüüsis katsetati läbi mitmeid erinevate kanalite kombinatsioone. Kappa indeksi järgi olid katsete kNNOLI1, kNNOLI2, kNNOLI3, kNNOLI4, kNNOLI5 ja kNNOLI6 tulemused väga lähedased (**Tabel 4**). Arvestades kNNOLI6 katse väiksemat sisendkanalite arvu valiti sügavamaks analüüsiks just see katse. Landsat-8 OLI esimese nelja kanali korreleeruvus taimkattega alal on väga suur ja seega kõigi nende piltide lisamine andmetöötlusesse suurendab ainult töö mahtu ja analüüsi tegemiseks kuluvat aega, kuid annab vähe paranemist tulemuste täpsuses. Teiste kanalite ja ülesvõtete kuupäevade kombinatsioonid ei suurendanud tulemuste kontrollis kappa väärtusi. Olulist negatiivset mõju kappa indeksile avaldas varakevadise kuupäeva ülesvõtte eemaldamine, mida on näha katsete kNNOLI6 ja kNNOLI9 võrdluses. Nende katsete kanalite kombinatsioonid on samad kuid kappa väärtus langes 17. märtsi pildi eemaldamisel märgatavalt.

Joonisel 1 on näha kNNOLI6 tulemuse näidis. Joonis 1 on ka läbi puhastatud metsamaad kirjeldava maskiga, mis on koostatud Järvelja takseerandmete ning Corine maakatte kaardi alusel (Sims, Lang 2011, CORINE 2004).

Visuaalselt on näha, et satelliidipildi klassifikatsioon langeb üldiselt kokku Järvelja metskonna eraldiste piiridega. Kuid on näha ka seda, et eraldiste sisemus moodustub tihti mitme erineva klassi pikslite segust. Põhjuseks on arvatavasti see, et metsad on üsna dünaamilised objektid ja pole tihtilugu selgelt eristuvad puhtpuistud nagu valitud õpetusalad olid. Lisaks lähedaste spektraalsete peegeldumisomadustega puu- ja taimeliigid võivad ka kergelt omavahel segamini minna ning kui 30 m piksli sisse satub ka mitut erinevat liiki puid, siis sellest moodustunud kombineeritud signatuur ei saagi täpselt kirjeldada ühte puuliiki.



Joonis 1. Landsat-8 OLI 2015. aasta aegrea piltide põhjal tehtud k-NN ennustus puistute liigilise koosseisu kohta Järvselja metskonnast kasutades 4 ($0,64 - 0,67\mu\text{m}$), 5 ($0,85 - 0,88\mu\text{m}$), 6 ($1,57 - 1,65\mu\text{m}$) ja 7 ($2,11 - 2,29\mu\text{m}$) multispektraalseid kanaleid ruumilahutusega 30 m.

Tabel 5. Klassifitseerimistulemuse kokkulangevus kontrollaladel pikslite kaupa Landsat-8 2015. aasta katse kNNOLI6 põhjal (Tabel 3)

Õpetus Kontroll	HB	KS noor	KS	KU	Lage	LM noor	LM	MA	Kokku	Kokku- langevus
HB	2	1	22	1	0	1	14	0	41	4,9%
KS noor	2	60	66	7	22	0	8	9	174	34,5%
KS	10	28	961	0	10	0	55	20	1084	88,7%
KU	0	3	17	197	4	0	9	34	264	74,6%
Lage	0	41	39	2	176	1	6	36	301	58,5%
LM noor	1	4	9	1	3	13	14	0	45	28,9%
LM	5	6	81	5	3	4	110	6	220	50,0%
MA	0	6	7	30	1	0	1	500	545	91,7%
Kokku	20	149	1202	243	219	19	217	605	2674	
Kokku- langevus	10,0%	40,3%	80,0%	81,1%	80,4%	68,4%	50,7%	82,6%		75,5%

Tabelist 5 on näha, et klassifitseeritud pikslid satuvad enamjaolt sama klassi koodiga kontrollaladele. Tabeli diagonaal väljendab korrektselt kokku langenud pikslite arvu ja sellest vastavalt üles või alla poole jäävad arvud nende pikslite arvu, mis sattusid mõne teist tüüpi kontrollala peale. Näiteks männikud eristuvad teistest puuliikidest küllaltki hästi ja võrdlus kontrollaladel annab kapp väärtust 0,78. Kokku männikuna klassifitseeritud 605 pikslit tervelt 500 asuvad ka kontrollaladel männikutes. Vähem piksleid on aga sattunud männikute määramisel lagedatele aladele, kuusikutesse ja kaasikutesse.

Ka kuusikud eristusid teistest väga hästi omades kapp väärtust 0,79. spektraalselt on nad segamini läinud vaid mõnede männikute pikslitega. Võimalik, et siin on mõjutajaks olnud mõnedes männikutes kasvav kuuse teine rinne.

Lehtpuupuistute omavaheline eristamine oli suurema veaga. Vanemad kaasikud klassifitseeriti kapp väärtusega 0,66 ja segadusi tekkis kohati nooremate kaasikute, sanglepikute, lagedate alade ja haavikutega. Analüüsides kaardilt noorte kaasikutena klassifitseeritud pikslite asukohti, mis olid määratud kontrollaladel vanaemate kaasikute aladele, selgus, et need asusid tihti eraldiste äärealadel. Sellised pikslid aga ulatuvad ka veidi eraldise piiridest välja, sisaldades sedasi endas spektraalset informatsiooni ka

naabereraldise kohta. Mõned noorte kaasikutena klassifitseeritud pikslid, mis asusid vanemate kaasikute kontrollaladel ja olid eraldiste keskmee lähedamal, pärinesid sellistest kaasikutest, mille vanus oli suhteliselt väike (14 - 19 aastat) Kuid üksikud pikslid sattusid ka üsna vanadesse kaasikutesse mille eraldiste vanused olid takseerandmestikus märgitud 69 aastat. Seda võib ehk kirjeldada sellega, et sellistest puistutes on sisemisi variatsioone, kus näiteks häiludes kasvavadki nooremad kased. Nooremad kaasikud ($\kappa=0,36$) on ka klassifitseeritud kontroll aladel küllaltki palju lagedatele aladele. Seda võib selgitada sellega, et spektraalset signatuuri mõjutab oluliselt puistu liitus. Noored puistud on tihti küllaltki hõredad ja seega mängib spektraalse signatuuri moodustamisel suurt rolli foon (Nilson 1994). Sedasi võib selgitada noorte puistute valesti klassifitseerimist lagedatena.

Noored sanglepikud tulid selles analüüsis küllaltki hästi välja, kuid analüüsi õpetus- ja kontrollalade valimi väiksuse tõttu ning klassifitseeritud 19 piksli põhjal võib võrdlemisi hea $\kappa=0,68$ olla siiski petlik. Vanemate sanglepikute ($\kappa=0,46$) puhul tekkis segadusi teiste lehtpuudega, peamiselt kaasikutega.

Haavikud selles analüüsis eriti selgelt ei eristunud ($\kappa=0,09$). Segamini läksid nad peamiselt kaasikutega. Ka siin võib probleemina välja tuua kontrollalade pindala väiksust. Lisaks esines neid uuritava alal puhtpuistutena väga vähe ja analüüsi oli võetud puistuid, kus haava osakaal oli alates 75 %.

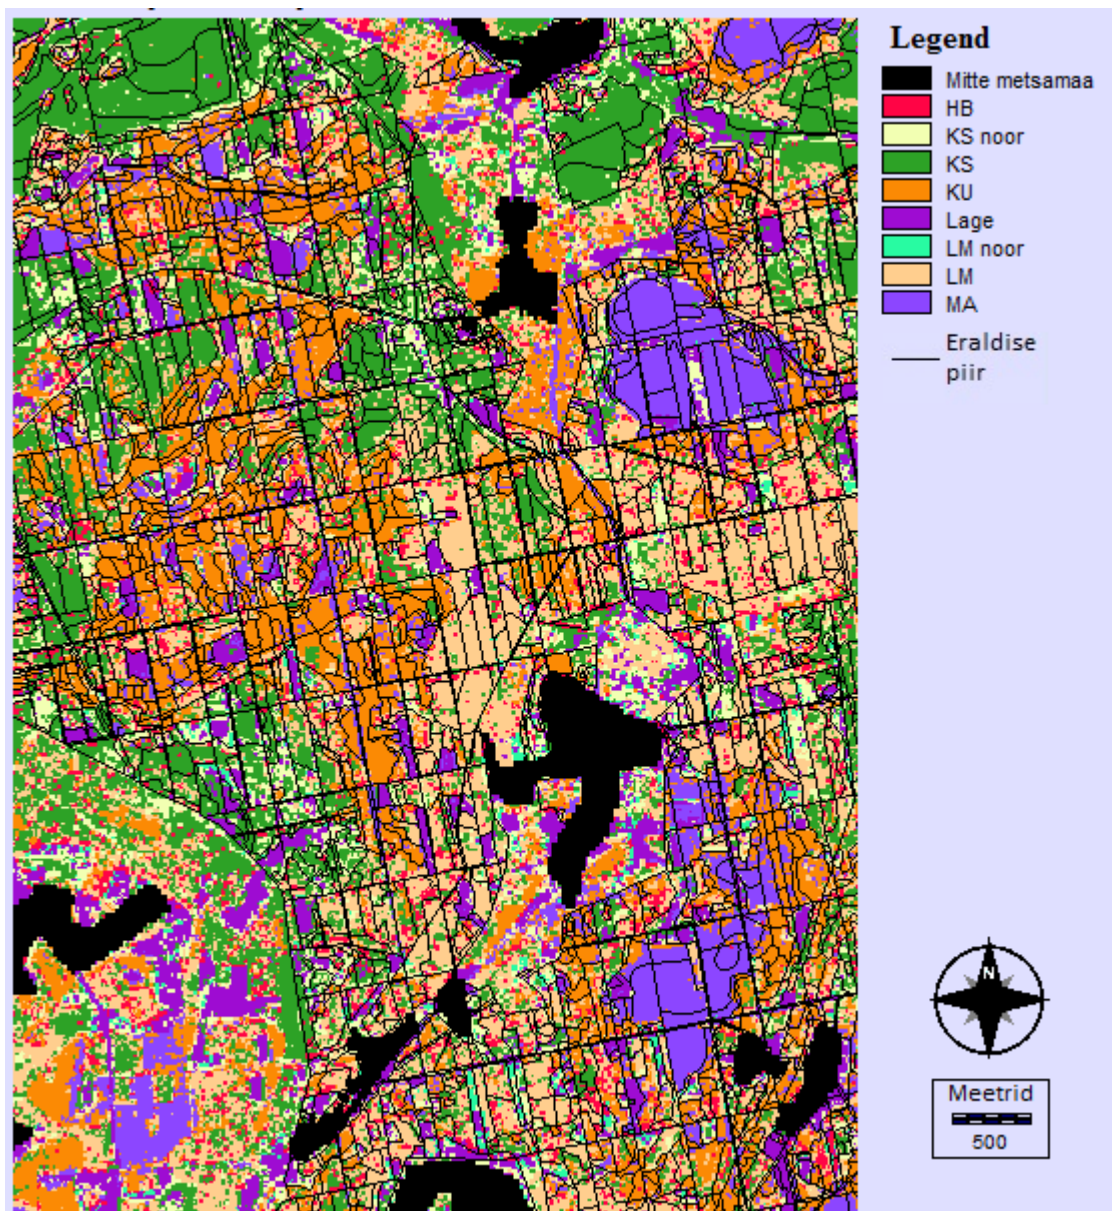
Lagedad alad klassifitseeriti võrdlemisi hästi kapp väärtusega 0,78. Segadusi tekkis peamiselt noorte kaasikutega (Tabel 5).

3.2 2015. aasta Sentinel-2 MSI piltide aegrida

Analoogselt Landsat-8 OLI andmete analüüsile, katsetati ka Sentinel-2 MSI piltide töötlemisel mitmete erinevate kanalite kombinatsioone k-NN analüüsis. Kappa näitajate järgi osutusid parimateks sarnased spektraalsed kanalid kui seda oli Landsat 8 OLI kombinatsioonide puhul. Kõrgete ja väga vähe varieeruvate kapp väärtustega olid katsed kNNMSI1, kNNMSI2, kNNMSI4 ja kNNMSI5 (Tabel 4). Analoogselt Landsat-8 OLI katsele otsustati lähemalt analüüsida katset kNNMSI5, milles on lainepikkustelt väga lähedased kanalite kombinatsioonid katsele kNNOLI6. Sentinel-2 (MSI) piltide

ruumilahutus maapinnal on kanalites erinev ja parema ruumilahutuse mõju uurimiseks teisendati 20 m resolutsiooniga pikslid 10 m suurusteks. Siin tuleb märkida seda, et lähteandmete informatsiooni osakaal selle teisenduse käigus ei suurenenud.

Sentinel-2 MSI k-NN katse kNNMSI5 tulemused joonisel 2 on visuaalselt küllaltki sarnaned (joonis 1) Landsat 8 andmetele tugineva parima sobivuse andnud katsega kNNOLI6, kuid on märgata ka mitmeid erinevusi. Sentinel-2 andmete parem ruumilahutus võimaldab kaardil täpsemalt lokaliseerida metsade sisemist varieeruvust. Osa eraldistest on aga ka pikslite enamuses klassifitseeritud teistsugusesse klassi kui Landsat 8 OLI andmetöötluse põhjal, kuigi õpetusalade sisendid ja kontrollalad olid mõlemal juhul samad. Siin võib erisuse üheks põhjuseks välja tuua selle, et kuigi mõlema satelliidi pildid pärinevad samast aastast, on need tehtud erinevatel kuupäevadel. Sentinel-2 andmeid 2015 aasta kohta oli antud ala kohta pilvevabalt saada alates augustist seega jättes aegrea analüüsist täielikult välja kevade ja suve esimese poole. Kuid Landsat 8 pilvituid pilte Järvselja metsade kohta oli saadaval antud aasta kohta nii kevadest, suvest kui ka sügisest. Omaette küsimus on ka see, kui hästi need pildid satuvad kokku erinevate puuliikide fenoloogiliste muutustega ajas ning, kas on tabatud see hetk, millal üks puuliik on juba jõudnud järgmisesse fenofaasi aga teine sarnase spektriga puu liik veel mitte. Kui pildid on sattunud fenoloogia muutuste vahelisele ajale võib see aidata muidu sarnase spektriga puid teineteisest eristada (Nagendra 2001, Kremer, Running 1993, Wolter et al. 1995).



Joonis 2. Sentinel-2 MSI 2015. aasta aegrea piltide põhjal tehtud k-NN ennustus Järvelja metskonnast kasutades 4 (0,665 μm), 8A (0,865 μm), 11 (1,610 μm) ja 12 (2,190 μm) multispektraalseid kanaleid resolutsiooniga 10 m.

Tabel 6. Klassifitseerimistulemuse kokkulangevus kontrollaladel pikslite kaupa Sentinel-2 2015 aasta katse kNNMSI5 põhjal (Tabel 3)

Õpetus Kontroll	HB	KS noor	KS	KU	Lage	LM noor	LM	MA	Kokku	Kokku- langevus
HB	41	89	87	46	5	3	97	7	375	10,9%
KS noor	64	590	367	25	195	57	186	77	1561	37,8%
KS	206	696	8181	69	141	39	501	29	9862	83,0%
KU	33	23	18	2014	30	8	100	120	2346	85,8%
Lage	33	268	176	41	1920	32	86	109	2665	72,0%
LM noor	29	88	8	5	104	70	106	1	411	17,0%
LM	114	38	114	82	28	13	1540	23	1952	78,9%
MA	16	19	12	606	9	19	72	4179	4932	84,7%
Kokku	536	1811	8963	2888	2432	241	2688	4545	24104	
Kokku- langevus	7,6%	32,6%	91,3%	69,7%	78,9%	29,0%	57,3%	91,9%		76,9%

Tabelist 6 võib näha üsna sarnast trendi nagu tabelis 5, kus suurem osa klassifitseeritud pikslite koguarvust satub sama klassi kontrollaladele. Kõigi klasside üldine Kappa indeks Sentinel-2 katse kNNMSI5 andmete põhjal on 0,70 ning see natuke suurem kui Landsat 8 andmete korral kus $\kappa=0,65$, kuid see erinevus on üsna väike. Eraldi klasside kohta on kappa väärtused Sentinel-2 ennustuste korral järgmised: haavikud ($\kappa=0,06$), noored kaasikud ($\kappa=0,28$), kaasikud ($\kappa=0,85$), kuusikud ($\kappa=0,66$), lagedad alad ($\kappa=0,76$), noored sanglepikud ($\kappa=0,29$), sanglepikud ($\kappa=0,54$) ja männikud ($\kappa=0,90$). Need tulemused on võrreldavad Landsat 8 katse kNNOLI6 andmetel saadud tulemustega, kuid selgelt on mõni klass Sentinel-2 puhul eristunud paremini (männikud, kaasikud) ja mõni jällegi kehvemini (noored sanglepikud, kuusikud).

Selgub, et haavikute eristamine teistest lehtpuudest on problemaatiline, vähemalt antud andmestiku kasutades. Õpetus- ja kontrollalade vähesus ja üldine spektraalne sarnasus teiste lehtpuudega on klassifitseerimisel loob olukorra, kus korrektselt haavikute klassi määratud piksleid on tunduvalt vähem kui haaviku klassina määratud piksleid, mis tegelikkuses on kaasikud või sanglepikud (Tabel 6). Noorte sanglepikute puhul on küll kõige rohkem piksleid klassifitseeritud õigetele kontrollaladele, kuid seda vaid marginaalselt rohkem kui teistele ja suur osa pikslitest on läinud segamini noorte ja vanemate kaasikute ning lagedate aladega.

Noorte kaasikute määramisel olid sarnased probleemid nagu Landsat 8 satelliitpiltide puhul. Puistute aegridu rangetesse vanusevahemikesse liigitada on problemaatiline, sest noore puistu spektraalse signatuuri muutus puistu vananedes on kompleksne. Vanema puistu signatuur küll stabiliseerub ja muutub ajas vähe (Nilson 1994), kuid rangelt klassidesse rühmitamisel vanusepiiri määramine on üsna subjektiivne otsus.

Vanemate kaasikute klassifitseerimine õnnestus Sentinel-2 andmetel väga hästi, mida näitas kõrge kappa väärtus. Kuusikud määrati k-NN analüüsis võrdlemisi hästi, kuid üsna palju määrati neid kontrollaladel männikutesse. Lagedate alade määramine õnnestus võrdlemisi hästi ja on oma tulemustelt väga sarnane Landsat-8 andmetega tehtud analüüsiga. Sanglepikud klassifitseeriti neil andmetel keskmiselt hästi, kuid tihtilugu määrati selle klassi pikseleid ka kaasikutesse. Männikud eristusid teisest klassidest aga erakordselt hästi.

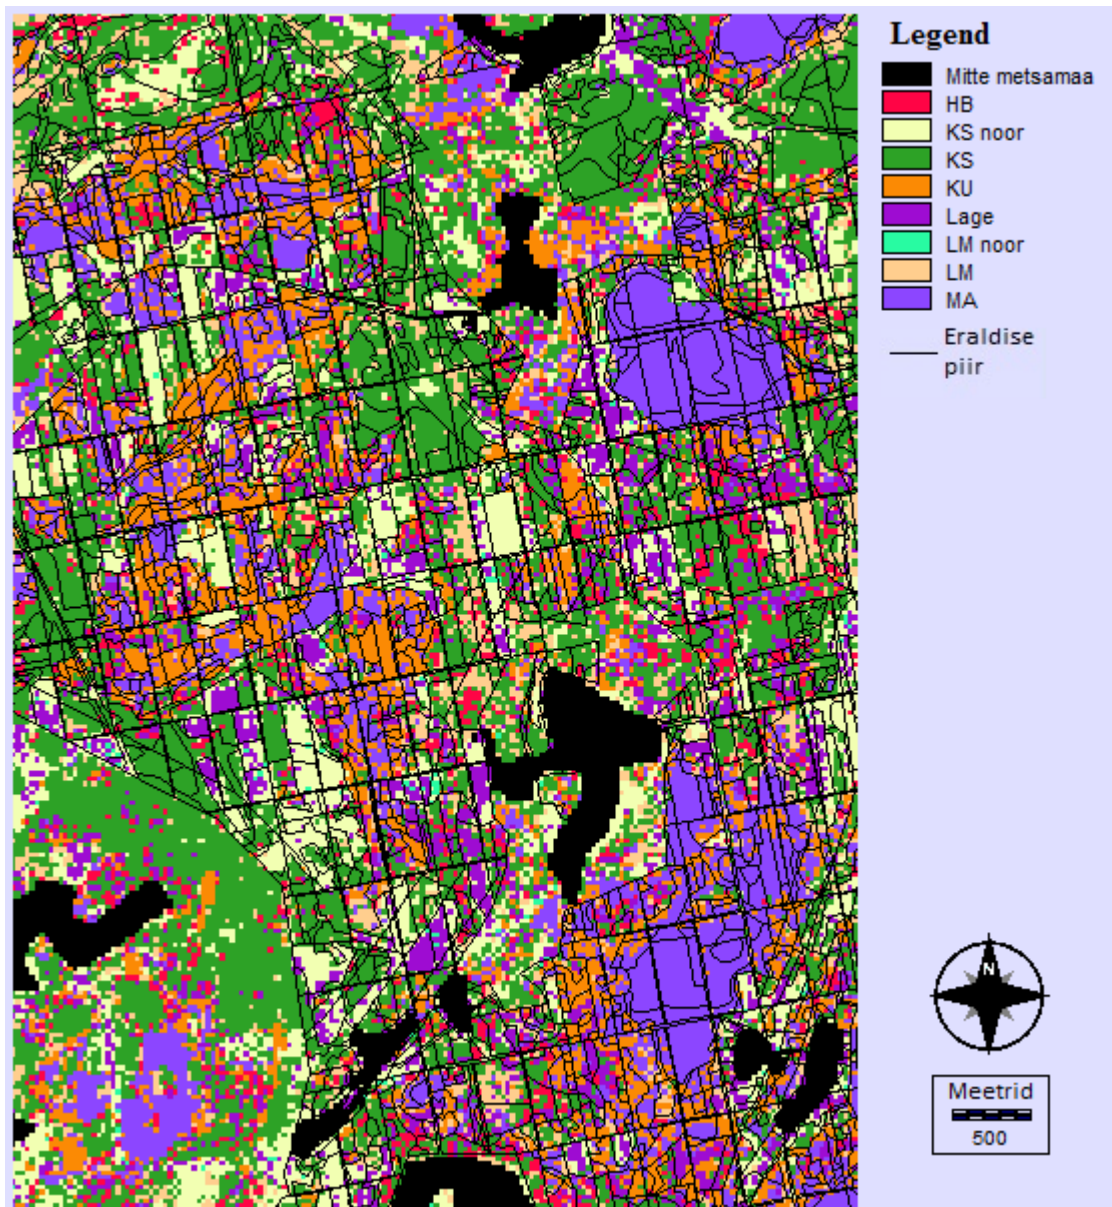
3.3 2000. aasta Landsat-7 ETM+ piltide aegrida

Aasta 2000 aegrea Landsat 7 ETM+ satelliitpiltide põhjal tehtud analüüsis kasutati võrreldes 2015 aasta analüüsiga veidi erinevaid õpetus- ja kontrollalasid. Seda seetõttu, et antud aastatele ajaliselt kõige lähedasemad takseerandmestikud erinesid teineteisest mitmeti ning näiteks noorte puistute valimisel ei ole võimalik neid mõlema aasta analüüsi puhul samana hoida.

Sarnaselt 2015 aasta analüüsidele Landsat-8 ja Sentinel-2 multispektraalsete sensorite piltide põhjal valiti ka Landsat 7 ETM+ puhul välja sarnaste lainepikkustega kanalite kombinatsioonid k-NN analüüsiks. Kõrgete kappa näitajatega olid katsed kNNETM+1, kNNETM+2, kNNETM+3 ja kNNETM+5 (Tabel 4). Täpsemaks analüüsiks kasutati katse kNNETM+5 tulemusi, kuna selle katse lainepikkuste kombinatsioon oli väga sarnane katsete kNNOLI6 ja kNNMSI5 omadega. Katsete kNNETM+1, kNNETM+2 ja kNNETM+4 kanalite kombinatsioonid on mahukamad kui katse kNNETM+5 omad, kuid nende kappa väärtused on väiksemad. Seega lisades analüüsi rohkem kanaleid ei tähenda see alati klassifitseerimise tulemuste tõusu. Veel selgus, kui uurimusest välja jätta 30. septembri ülesvõtte, siis on näha ka klassifitseerimise tulemuslikkuse langust. Seda näitab katsete kNNETM+5 ja kNNETM+7 võrdlus, kus sama kanalitse kombinatsiooni korral

kuid erinevate aegridadega analüüsis annab paremaid tulemusi sügise piltide analüüsi kaasamine.

Joonisel 3 kujutatud pilditööstlusest on visuaalselt näha, et üldjoones jällegi kattub klassifikatsioon eraldiste piiridega. Kuid paljudes kohtades on ka suurel määral erinevate klasside segu, see võib tuleneda sellest, et vastavates eraldistes ongi tegemist segametsaga, kus on esindatud mitmed erinevad klassifitseeritud puuliigid.



Joonis 3. Landsat-7 ETM+ 2000. aasta aegrea piltide põhjal tehtud k-NN ennustus Järvelja metskonnast kasutades 3 (0,63 - 0,69 μm) , 4 (0,77 - 0,90 μm) , 5 (1,55 - 1,75 μm) ja 7 (2,09 - 2,35 μm) multispektraalseid kanaleid ruumilahutusega 30 m.

Tabel 7. Klassifitseerimistulemuse kokkulangevus kontrollaladel pikslite kaupa Landsat-7 ETM+ 2000 aasta katse kNNETM+5 põhjal (Tabel 3)

Õpetus Kontroll	HB	KS noor	KS	KU	Lage	LM noor	LM	MA	Kokku	Kokku- langevus
HB	14	0	14	4	8	0	0	3	43	32,6%
KS noor	2	128	34	2	60	1	10	0	237	54,0%
KS	22	25	317	14	12	0	13	5	408	77,7%
KU	4	12	19	122	4	1	14	28	204	59,8%
Lage	1	77	21	13	215	5	5	36	373	57,6%
LM noor	1	20	5	1	35	1	3	0	66	1,5%
LM	18	1	40	6	6	0	29	4	104	27,9%
MA	4	4	9	14	0	0	7	415	453	91,6%
Kokku	66	267	459	176	340	8	81	491	1888	
Kokku- langevus	21,2%	47,9%	69,1%	69,3%	63,2%	12,5%	35,8%	84,5%		65,7%

Landsat-7 ETM+ 2000. aasta aegrea koondatud k-NN analüüsi võrdlusel kontrollaladega saadi kapp üldiseks väärtuseks 0,58, mis on veidi madalam uuemate sensorite andmetel põhinevate katsetega võrreldes. Selle põhjuseks on tõenäoliselt õpetus- ja kontrollalade erinevus, mis annab märku sellest, kui tundlik selline analüüs nende alade valikule. Lisaks mõjutab tulemust ka ETM+ sensori väiksem radiomeetriline lahutusvõime võrreldes OLI ja MSI sensoritega ning piltide ülesvõtete aegade erinevus.

Tabelist 7 on näha taaskord üldist ennustuste ja kontrolli kokkulangevust mööda tabeli diagonaali. Nagu ka 2015. aasta analüüside puhul ei eristu lehtpuud nagu haab ja sanglepp omavahel eriti hästi. Haavikute klassi $\kappa=0,19$ on küll veidi kõrgem kui eelnevate hinnangute puhul, kuid siiski on õigesti klassifitseeritud pikslite arv alles järjekorras kolmandal kohal pärast kaasikuid ja sanglepikuid. Noored kaasikud eristusid selle analüüsi puhul veidi selgemalt, kui 2015. aasta andmestike põhjal, kuid siiski kõigest noorte kaasikutena klassifitseeritud pikslite seast alla poolte klassifitseeriti õigesti ($\kappa=0,40$). Vanemad kaasikud, kuusikud, lagedad alad ja männikud eristusid teistest võrdlemisi hästi igaüks vastavalt kapp indeksiga 0,61; 0,66; 0,54 ja 0,80.

Noorte sanglepikude klassifitseerimist antud andmetel võib lugeda ebaõnnestunuks, kuna seda klassi juhtus kontrollaladesse üldse väga harva ning õigesti klassifitseeriti vaid üks piksel kaheksast andes kappa 0,09. Vanemad sanglepikud klassifitseeriti üldiselt rahuldava kokkulangevusega ($\kappa=0,32$).

4 ARUTELU

Kolme erineva satelliidi ülesvõtetelt tehtud ennustused kasutades k-lähima naabri klassifitseerimistehnikat andsid üksteisega võrreldavaid tulemusi. Uurimustöös kasutatud erinevatel aegadel tehtud pildid aitasid kaasa sarnaste spektraalse peegeldumisega puuliikide eristamisel. Kasutades multispektraalseid satelliitpiltide aegridu on Põhja-Ameerikas Landsat-5 TM (Thematic Mapper) andmeid kasutades klassifitseeritud üldise 83,2 % täpsusega mitmeid erinevaid puuliike. Tundes puuliikide fenoloogilisi erinevusi suudeti valida satelliitülesvõtete aeg sedasi, et liigid, mis enamiku ajast on spektraalselt ülisarnased, olid ülesvõtte ajal erinevates fenoloogilistes etappides tekitades sedasi neis spektri signatuuri erinevusi (Wolter et al. 1995). Selles uurimuses oli üldisteks täpsusteks katsetes kNNOLI6 75,5%, kNNMSI5 76,9% ja kNNETM+5 65,7%.

Järvelja Öppe- ja Katsemetskonna aladel õnnestus kõige edukamalt eristada puistu tüüpidest männikuid kappa väärtusega 0,78 kuni 0,90, näidates väga tugevat seost tehtud ennustuste ja kontrollaladel oleva reaalsuse vahel. Väga hästi eristusid ka vanemad kaasikud (kappa 0,61 - 0,85), kuusikud (kappa 0,66 - 0,79) ja lagedad alad (kappa 0,54 - 0,78). Noorte kaasikute klassifitseerimisel tekkis tihti segadusi lagedate aladega, mis on tõenäoliselt tingitud sellest, et väga noorte puistute puhul moodustab peamise spektri signatuuri foon, mille määrab osaliselt alustaimestik. Filip Hájek (2005) on oma uurimuses leidnud, et kasutades Ikonos satelliidi pilte on võimalik kaasikuid, kuusikuid ja lagedaid alasid eristada kappa väärtustega vastavalt 0,53; 0,98 ja 0,90. Lisaks neile oli selles uurimuses klassifitseeritud ka lehise ja pöõgi metsi, varjutatud metsa alasid, põlde ning inimasustusi. Varjutatud alad läksid tihti segamini kuusikutega. Käesolevas uurimuses varjude mõju metsa alade klassifitseerimisel eraldi ei käsitletud, kuid tulevastes uurimustes võib sellele tähelepanu pöörata.

Sanglepikute kaardistamine andis vahelduvaid tulemusi. Tulemite kokkulangevuse varieeruvust võib seletada erinevate satelliitpiltide aegrea ülesvõtete kuupäevade erisusega sedasi kord fenoloogia erisust tabades ja teine kord mitte. Haavikute klassifitseerimast võib lugeda ebaõnnestunuks, kuna kokkulangevus oli kontrollaladel sama klassiga väga väike. Seda võis põhjustada õpetus- ja kontrollalade vähesus antud puuliigi osas.

Õpetusalade valik on k-NN klassifitseerimise puhul kriitiline etapp. Täpne kirjeldus tegelikkusest maapinnal on vajalik, kuna varieeruvus metsas mõjutab ka peegeldunud valguse spektrit. Alade valikul on oluline leida piisavalt näidiseid sarnastest objektidest, et moodustada detailne spektraalne signatuur iga klassi kohta. Tehes koostööd taksaatoritega on arvatavasti võimalik valida selgemalt eristuvad õpetusalad, sedasi õpetusalade kvaliteeti parandades ning võimaldades vähendada õpetusalade pindalasid (Wolter et al. 1995, Martin et al. 1998).

Multispektraalsete satelliitpiltide kasutamisel on oluline valida õigete lainepikkustega kanalite kombinatsioonid. Taimeliikide biokeemiline erinevus taimelehtedes, mis sisaldavad erinevas koguses vett, fotosünteesilisi pigmente ja erinevaid süsivesikuid, tekitab tagasi peegelduvas kiirguses mitmete liikide vahel erinevusi. Lisaks mõjutavad spektrit ka lehtede morfoloogia ja võrastiku struktuur (Nilson 1994, Fassnacht et al. 2016). Kasutades puude peegeldumisspektrit ennustavaid mudeleid, mis võtavad neid tegureid arvesse, on ehk võimalik parandada klassifitseerimise tulemusi. Hüperspektraalsete sensorite pilte kasutanud uuringud on näidanud, et häid tulemusi saab nende spektraalkanalite alusel, mille puhul on võimalik puude peegeldumisspektrit ka mudelitega hästi simuleerida. Kuid samas võivad ka väljaspool neid lainepikkuste vahemike olevad kanalid parandada klassifitseerimise tulemust, teised aga võivad seda ka mingil määral vähendada, tekitades analüüsi vaid müra (Fassnacht et al. 2016). Ka selle uurimustöö juures analüüsitud kanalikombinatsioonide valikul tähendati, et mitmete kanalite lisamine uurimusse ei tõstnud ennustuste täpsust oluliselt ja mõne kanali lisamisel tekkiv müra isegi vähendas seda (tabel 4).

Kappa väärtuste alusel võib uurimustöös saadud tulemusi kirjeldada Landis ja Koch (1977) jaotuse alusel oluliselt kokkulangevateks. Mõne puuliigi korral lausa peaaegu ideaalselt kokkulangevateks, teiste korral aga viletsalt kokkulangevateks. Need hinnangud on küll subjektiivsed, kuid annavad mingisuguse ettekujutuse tulemuste kvaliteedist. Kappa indeks peaks teoreetiliselt olema robustsem kui lihtne protsendiline kokkulangevuse arvutus kuna kappa võtab arvesse ka kokkulangevust juhuslikkuse alusel (Landis, Koch 1977).

Järvelja Õppe- ja Katsemetskonna metsade kaardistamine kaugseire andmeid kasutades on võimalik ja on tõenäoliselt abiks mitmete kaitse ja metsamajanduslike tegevuste jaoks. Kombineerides taksaatorite tööd ja kaugseirest saadud tulemusi on võimalik täpsemalt kaardistada metsi ka väljaspool Järvelja piirkonda. Looduskaitse valdkonnas võivad

liigilise koosseisu kaardid olla abiks liigirikkuse hindamisel, haruldaste liikide tuvastamisel ning invasiivsete liikide leviku määramisel.

KOKKUVÕTE

Multispektraalsete satelliitpiltide analüüs puistute liigilise koosseisu hindamiseks on leidnud laialdast kasutust suurte alade kaardistamiseks. Erinevate kuupäevade ülesvõtete kaasamine andmetöötlusesse võimaldab eristada muidu sarnaste spektraalsete omadustega puuliike teineteisest, kui pildid on tehtud ajal, mil üks liikidest on fenoloogiliselt teises etapis võrreldes teisega.

Kasutatud rasterandmed pärinevad kolmelt erinevalt satelliidilt, kuid nende sensorite lainepikkuste kanalid võimaldavad kasutada sarnaseid kombinatsioone. Töö käigus uuriti metsi 2015 aasta Landsat 8 OLI ja Sentinel-2 MSI ja 2000 aasta Landsat 7 ETM+ aegrea andmeid kasutades.

Uurimustöös on kasutatud k-NN analüüsi kaheksasse erinevasse klassi kuuluvate õpetusaladega. Töö tulemusi on hinnatud analoogsete kontrollaladega ning nende headust hinnati kasutades Kappa kokkulangevuse indeksit. Uuritavateks klassideks olid haavikud, noored kaasikud, vanemad kaasikud, kuusikud, noored sanglepikud, vanemad sanglepikud, männikud ja lagedad alad.

Järvelja Õppe- ja Katsemetskonna metsade liigilise koosseisu uurimisel kaugseire meetodeid kasutades leiti, et männikuid, vanemaid kaasikuid, kuusikuid ja lagedaid alasid on võimalik teistest eristada küllaltki edukalt saavutades kontrollaladega võrdluses kappa indeksi väärtuseid kuni 0,9.

Erinevaid satelliitülesvõtete kanalikombinatsioone katsetades selgus, et andmemahu suurendamine, lisades taimkatte alal tugevalt korreleeruvaid kanaleid, ei tõsta oluliselt klassifitseerimistulemuste headust ja mõnel juhul võib sellest kaasnev müra seda isegi veidi vähendada.

Olulist negatiivset mõju, uuritud klasside kaardistamisel, avaldas mõne kuupäeva piltide eemaldamine analüüsist. Aegridade analüüs põhineb ülesvõtete leidmisel, mis tabavad erinevate liikide fenoloogilisi erisusi.

Tulevastes uurimustes peaks kasutama täiendavaid tunnuseid puistute kirjeldamisel, et tõsta klassifitseerimise täpsust. Tehes lähedast koostööd metsataksaatoritega, saab luua täpsemaid liigilise koosseisu kaarte suurtele aladele.

KASUTATUD KIRJANDUS

- Beckett, K.P., Freer-Smith, P., Taylor, G.** (2000), Particulate pollution capture by urban trees: effect of species and windspeed, - *Global Change Biology*, vol. 6, no. 8, pp. 995-1003.
- Calfapietra, C., Fares, S., Manes, F., Morani, A., Sgrigna, G., Loreto, F.** (2013), Role of Biogenic Volatile Organic Compounds (BVOC) emitted by urban trees on ozone concentration in cities: A review, - *Environmental Pollution*, vol. 183, no. 1, pp. 71-80.
- Cohen, J.** (1960), A Coefficient of Agreement for Nominal Scales, - *Educational and Psychological Measurement*, vol. 20, no. 1, pp. 37-46.
- CORINE.** (2004) CORINE Land Cover 2000, - *Keskkonnaagentuur*, Tallinn.
- Fassnacht, F.E., Latifi, H., Sterenczak, K., Modzelewska, A., Lefsky, M., Waser, L.T., Straub, C., Ghosh, A.** (2016), Review of studies on tree species classification from remotely sensed data, - *Remote Sensing of Environment*, vol. 186, no. 1, pp. 64-87.
- Hájek, F.** (2005). Object-oriented classification of remote sensing data for the identification of tree species composition.- *Proceedings of ForestSat 2005 conference*. Prague, Czech Republic
- Hoffer, R., Johannsen, C.** (1969), Ecological potentials in spectral signature analysis, - *Remote sensing in ecology*, vol. 1, no 1, pp 1-16.
- Jansson, G., Angelstam, P.** (1999), Threshold levels of habitat composition for the presence of the long-tailed tit (*Aegithalos caudatus*) in a boreal landscape, - *Landscape Ecology*, vol. 14, no. 3, pp. 283-290.
- Järvselja loodus. - *SA Järvselja Õppe- ja Katsemetskond*, [WWW]. <http://jarvselja.ee/sihtasutusest/jarvselja-loodus/> (30.04.2017) .
- Järvselja Metsamajandamise Infosüsteem (2017a), Puistute jagunemine peapuuliigi järgi, - *Eesti Maaülikool*, [WWW]. <https://jarvselja.emu.ee/index.php?do=yvpeapuuliik> (30.04.2017) .
- Järvselja Metsamajandamise Infosüsteem (2017b), Tehtud uuendusraied, - *Eesti Maaülikool*, [WWW]. Available: <https://jarvselja.emu.ee/index.php?do=teht-ur> (30.04.2017) .
- Järvselja Metsamajandamise Infosüsteem (2017c), Ülevaade kõlvikuliikidest, - *Eesti Maaülikool*, [WWW]. Available: <https://jarvselja.emu.ee/index.php?do=yvkolvik> (30.04.2017) .

- Katila, M., Tomppo, E.** (2002), Stratification by ancillary data in multisource forest inventories employing k-nearest-neighbour estimation, - *Canadian Journal of Forest Research*, vol. 32, no. 9, pp. 1548-1561.
- Kremer, R.G., Running, S.W.** (1993), Community type differentiation using NOAA/AVHRR data within a sagebrush-steppe ecosystem, - *Remote Sensing of Environment*, vol 46, no. 3, pp, 311-318.
- Landis, J.R., Koch, G.G.** (1977), The measurement of observer agreement for categorical data, - *Biometrics*, vol. 33, no. 1, pp. 159-174.
- Martin, M.E., Newman, S.D., Aber, J.D., Congalton, R.G.** (1998), Determining forest species composition using high spectral resolution remote sensing data, - *Remote Sensing of Environment*, vol. 65, no. 3, pp. 249-254.
- McRoberts, R.E., Nelson, M.D., Wendt, D.G.** (2002), Stratified estimation of forest area using satellite imagery, inventory data, and the k -Nearest Neighbors technique, - *Remote Sensing of Environment*, vol. 82, no. 2-3, pp. 457-468.
- Metsa korraldamise juhend. (Vastu võetud 16.01.2009, muudetud, täiendatud, viimati jõustunud 25.02.2017). - *Riigi Teataja* [WWW]
<https://www.riigiteataja.ee/akt/122022017011> (21.05.2017).
- Metsanduslik info. - *SA Järvselja Õppe- ja Katsemetskond*, [WWW].
<http://jarvselja.ee/sihtasutusest/metsanduslik-info/> (30.04.2017) .
- Nagendra, H.** (2001), Using remote sensing to assess biodiversity, - *International Journal of Remote Sensing*, vol. 22, no. 12, pp. 2377-2400.
- Nilson, T.** (1994), Metsade kaugseire alused, - Tartu: Eesti Metsaamet. 160 lk.
- Nilson, T., Peterson, U.** (1994), Age dependence of forest reflectance: Analysis of main driving factors, - *Remote Sensing of Environment*, vol. 48, no. 3, pp. 319 - 331.
- Noe, S.M., Niinemets, Ü., Krasnova, A., Krasnov, D., Motallebi, A., Kängsepp, V., Jõgiste, K., Hõrrak, U., Komsaare, K., Mirme, S., Vana, M., Tammet, H., Bäck, J., Vesala, T., Kulmala, M., Petäjä, T., Kangur, A.** (2015). SMEAR Estonia: Perspectives of a large-scale forest ecosystem – atmosphere research infrastructure. – *Forestry Studies / Metsanduslikud Uurimused*, Vol. 63, pp. 56–84.
- Ørka, H.O., Dalponte, M., Gobakken, T., Næsset, E., Ene, L.T.** (2013), Characterizing forest species composition using multiple remote sensing data sources and inventory approaches, - *Scandinavian Journal of Forest Research*, vol. 28, no. 7, pp. 677-688.
- Salovaara, K.J., Thessler, S., Malik, R.N., Tuomisto, H.** (2005), Classification of Amazonian primary rain forest vegetation using Landsat ETM+ satellite imagery, - *Remote Sensing of Environment*, vol. 97, no. 1, pp. 39-51.

Sims, A., Lang, M. (2011), SA Järvselja Öppe- ja Katsemetskond 2010-2011 takseerandmed ver 1.0, - *Eesti Maaülikool*, Tartu.

Thessler, S., Ruokolainen, K., Tuomisto, H., Tomppo, E. (2005), Mapping gradual landscape-scale floristic changes in Amazonian primary rain forests by combining ordination and remote sensing, - *Global Ecology and Biogeography*, vol. 14, no. 4, pp. 315-325.

Tomppo, E., Halme, M. (2004), Using coarse scale forest variables as ancillary information and weighting of variables in k-NN estimation: a genetic algorithm approach, - *Remote Sensing of Environment*, vol. 92, no. 1, pp. 1-20.

Wolter, P.T., Mladenoff, D.J., Host, G.E., Crow, T.R. (1995), Improved forest classification in the northern lake states using multi-temporal Landsat imagery, - *Photogrammetric Engineering & Remote Sensing*, vol. 61, no. 9, pp. 1129-1143.

ESTIMATION OF SPECIES COMPOSITION IN FOREST STANDS USING MULTISPECTRAL SATELLITE IMAGES

SUMMARY

Multispectral satellite imagery has been widely used to estimate stand species composition over large areas. Using images from different dates in data processing helps to separate species with similar spectral signatures. When trees are in different phenological stages the similarities between them diverge.

Raster data used in this study comes from three different satellite sensors, but the sensors provide radiation measurements at similar combinations of wavelengths. In this study Landsat-8 OLI and Sentinel-2 MSI images from year 2015 and Landsat-7 ETM+ time series from year 2000 were used.

In this study k-nearest neighbour algorithm was used to identify eight different categories of training areas. Results of this analysis has been evaluated using control areas-based Kappa Index of Agreement (KIA). The study subject classes were aspen, young birch, older birch, spruce, younger black alder, older black alder, pine stands and treeless areas.

By using remote sensing methods in Järvelja Experimental Forestry station stands of pine, older birch, spruce, and non-forested areas can be relatively well distinguished, when compared with control areas, reaching kappa index of agreement values up to 0.9.

Testing different satellite band combinations showed, that increasing the amount of data by adding spectral bands, that strongly correlate over vegetation areas, does not increase the quality of classification. And on some occasions the spectral noise coming from added bands may even hinder it a little.

Removing some dates from the time series analysis had significant negative effect on the classification of data. Time series analysis is based on using the images that capture the different phenological stages of different species.

It is advised to use additional descriptive features in future studies, to increase the classification accuracy. By working closely with forest surveyors, it is possible to make more accurate species composition maps over large areas.

Lihtlitsents lõputöö salvestamiseks ja üldsusele kättesaadavaks tegemiseks ning juhendaja(te) kinnitus lõputöö kaitsmisele lubamise kohta

Mina, Mihkel Kaha,
sünniaeg 15.04.1992,

1. annan Eesti Maaülikoolile tasuta loa (lihtlitsentsi) enda loodud lõputöö
„Puistute liigilise koosseisu hindamine multispektraalsete satelliitpiltide põhjal“,

mille juhendaja on Mait Lang ,

- 1.1. salvestamiseks säilitamise eesmärgil,
 - 1.2. digiarhiivi DSpace lisamiseks ja
 - 1.3. veebikeskkonnas üldsusele kättesaadavaks tegemiseks
- kuni autoriõiguse kehtivuse tähtaja lõppemiseni;
2. olen teadlik, et punktis 1 nimetatud õigused jäävad alles ka autorile;
 3. kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest tulenevaid õigusi.

Lõputöö autor _____

(allkiri)

Tartu, _____

(kuupäev)

Juhendaja(te) kinnitus lõputöö kaitsmisele lubamise kohta

Luban lõputöö kaitsmisele.

(juhendaja nimi ja allkiri)

(kuupäev)